

MÉTODOS DE GESTÃO DE MOBILIDADE PARA ESTAÇÕES RÁDIO BASE ROBÓTICAS

Iran V. P. Moura, L. F. Bueno

¹Trabalho de Graduação 1 e 2 do Curso de Bacharelado em Matemática
Computacional do Instituto de Ciência e Tecnologia
Universidade Federal de São Paulo (UNIFESP)
Av. Cesare Monsueto Giulio Lattes, 1201
Eugênio de Melo – São José dos Campos – SP – Brazil

victorpinheirojc@gmail.com

Abstract. *The immobile Radio Base Stations (RBSs) employed for wireless networks (usually mounted on metal towers or on top of buildings) limit the coverage provided to users by serving fixed locations, and are insensitive to changes on how users are distributed spatially. In this work we propose some mobility management methods for Robotic Radio Base Stations (RRBSs), which are RBSs mounted on Unmanned Aerial Vehicles (UAVs) featuring onboard Artificial Intelligence to dynamically adjust their positions over time, providing users with better service coverage. In the considered scenario all the users position is known over the time, so it is sought to optimize the position of ARBSs over time, through a meta-heuristic technique, to provide reasonable coverage for the network.*

Resumo. *Estações Rádio Base (ERBs) imóveis utilizadas para redes sem fio (geralmente montadas em torres metálicas ou no topo de prédios) limitam a cobertura fornecida aos usuários a locais fixos e são insensíveis a mudanças em como os usuários são distribuídos espacialmente. Neste trabalho propomos alguns métodos de gestão de mobilidade para Estações Rádio Base Robóticas (RRBSs), as quais constituem o conjunto rádio e antena montado em veículos aéreos autônomos com Inteligência Artificial embarcada, os quais ajustarão dinamicamente suas posições de acordo com a movimentação dos usuários, fornecendo assim uma melhor cobertura à rede. No cenário considerado a posição de todos os usuários é sempre conhecida, assim busca-se otimizar a posição das RRBSs ao longo do tempo por meio de uma técnica de otimização meta-heurística, de maneira a fornecer cobertura razoável para a rede, considerando a complexa mobilidade dos usuários.*

1. Introdução

Maximizar o número de usuários conectados minimizando o custo do serviço é um desafio importante e constante, que deve ser enfrentado independentemente das características da rede. Os usuários também esperam uma cobertura confiável e ampla, ambos requisitos de qualidade que as redes modernas devem cumprir. Atender a essas expectativas é difícil,

seja em ambientes internos ou externos, principalmente devido à incerteza resultante da locomoção do usuário e da natureza dinâmica do uso da rede sem fio.

Existem situações em que uma área pode estar cheia de usuários, o que faz aumentar a demanda por serviços de rede, e depois de um curto período poderia estar quase vazia. Rádios e antenas dispostos em locais fixos, embora fáceis de implementar e implantar, não têm a flexibilidade necessária para acomodar os ambientes dinâmicos que as redes sem fio devem atender.

Os avanços nas redes de comunicação, redes veiculares e na robótica sugerem que as capacidades altamente desejáveis destas facilidades se tornam úteis para trazer melhorias ao serviço de redes sem fio. Por exemplo, a relocação autônoma de estações base em resposta ao comportamento de locomoção dos usuários é uma possível solução num futuro previsível, bem como a capacidade de se adaptar de forma flexível à forma geométrica da distribuição dos usuários à medida em que ela muda.

Uma tecnologia candidata clara para o fornecimento de tais capacidades é a ideia de Estações Rádio Base Robóticas (*RRBSs*) [Hayat et al. 2016], que serão capazes de responder aos padrões de uso geralmente complexos observados na maioria das situações enfrentadas pelas redes de comunicações sem fio [Rahmati et al. 2019]. No entanto, as *RRBSs* e soluções semelhantes também trarão novos desafios na estimativa de custos de desenvolvimento e implantação, dificultando a comparação de suas eventuais vantagens em relação às tecnologias atuais. Além disso, é razoável esperar que, em algumas situações, o padrão de deslocamento do usuário favoreça o uso de *RRBSs*, enquanto em outros, a atual tecnologia de antenas fixas pode ser mais rentável. Assim, avaliar a rentabilidade, a viabilidade técnica e outros aspectos dos *RRBSs*, e ser capaz de comparar consistente e coerentemente esses resultados com a tecnologia atual é um requisito fundamental para garantir a introdução bem-sucedida das *RRBSs* e tecnologias similares.

Atualmente, mesmo considerando regiões onde as *ERBs* não permeiam toda a região populada, o que provoca algumas zonas sem sinal para telecomunicações, a tecnologia de telecomunicações permeia razoavelmente os centros urbanos, onde existem plenas condições de se fazer planejamentos e implementar infraestrutura básica que funcione bem a longo prazo. Porém em cenários como desastres naturais, regiões pouco populadas ou carentes, e cenários diversos de guerra é difícil ou incerto trabalhar com a hipótese planejamento ou ter condições de construir infraestrutura necessária para operar sistemas de telecomunicações. Nestes cenários específicos, ter a mão um sistema flexível, rápido e independente de estrutura local torna-se uma alternativa para operar com sucesso as telecomunicações.

Em particular em cenários de guerra, a imprevisibilidade, a curta duração de certos tipos de operação, localidades sem infra-estrutura mínima, a geografia muitas vezes desfavorável, a urgência das operações e a crescente demanda de facilidades atreladas a redes de dados levantam a demanda de um serviço de telecomunicações flexível, ágil, de fácil desdobramento e reposição. Neste caso é razoável considerar as telecomunicações satelitais, porém as mesmas não possuem as mesmas características de flexibilidade de operação e fácil reposição da proposta de *RRBSs*, sem considerar o elevado custo de implementação.

Este trabalho aborda uma proposta de gestão de mobilidade para *RRBSs* pro-

pondo um modelo de simulação e otimização capaz de suportar a avaliação de tecnologias atuais e futuras em diferentes locais. O aspecto de simulação do modelo garante tanto a viabilidade técnica quanto a flexibilidade necessárias para realizar experimentos com tecnologias de ponta que ainda não estão totalmente desenvolvidas.

Outro aspecto importante do nosso modelo é o tratamento do comportamento do usuário, que é representado como um modelo probabilístico de Markov [Howard 2012] baseado em dados de uma região selecionada e que pode abranger um dia inteiro de atividade do usuário, o DIary-based TRAJectory Simulator (*DITRAS*) [Pappalardo and Simini 2016]. A alocação de antenas é representada através de um algoritmo de otimização meta-heurístico (Simulated Annealing - *SA*), que torna o modelo agnóstico à forma como os engenheiros abordariam o problema de otimização em um cenário futuro, pois a solução heurística abordará o ideal dentro de um grau razoável de fidelidade. O resultado da alocação de antenas feito pelo *SA* será comparado com a alocação feita por um algoritmo de clusterização por aprendizado de máquina, o Gaussian Mixture Model - *GMM*.

Após esta breve introdução, a seção 2 apresenta uma seleção de pesquisas atuais sobre estações base móveis, seção 3 fornece ao leitor os conceitos fundamentais usados em nossa investigação, e seção 4 apresenta a metodologia proposta para a avaliação de *RRBSs*, onde se encerra a primeira parte deste Trabalho de Graduação.

Na segunda parte do Trabalho de Graduação, na seção 5 discutiremos nossos resultados experimentais, e na seção 6 veremos as conclusões associadas.

2. Trabalhos relacionados

Os sistemas de comunicações móveis (telefonia celular, por exemplo) são os principais impulsionadores do mercado de comunicação sem fio. A arquitetura básica de um sistema móvel, independentemente de sua tecnologia adotada, é formada por três componentes: dispositivos móveis (por exemplo, celulares), Centro de Comutação e Controle e *ERBs* [Rappaport 2001]. Um exemplo real de tais sistemas é mostrado na Figura 1, que ilustra a divisão da área de cobertura em partes menores, conhecidas como células. Cada célula é atendida por uma *ERB* e inclui transceptores com potência de transmissão limitada, antenas posicionadas e técnicas para reutilizar bandas de frequência, todas configuradas para fornecer comunicação com dispositivos móveis (por exemplo, telefones celulares) dentro de sua área de cobertura.




Figura 1. Estrutura básica do sistema de telefonia celular.

A característica fixa das *ERBs* (geralmente posicionada no topo das torres metálicas) é muitas vezes uma desvantagem que afeta a cobertura oferecida ao usuário, já que há propensão a obstáculos físicos bloqueando temporariamente a visada direta entre as antenas e os usuários (que estão se movendo), causando zonas de silêncio (zonas sem cobertura de sinal). Esses fatores são agravados pela constante dependência do usuário a uma conexão muitas vezes permanente, um requisito em grande parte dos aplicativos de dispositivos móveis conectados a Internet. Além disso, os locais onde ficam as *ERBs* são escolhidos para fornecer a maior cobertura a uma localidade, mas essa opção não considera o número de usuários que a *ERB* atende [Padueli 2012]. Em resumo, a configuração fixa empregada a *ERB* apresenta muitas limitações que afetam negativamente a cobertura, além de ser ineficiente em termos de uso de energia (insensibilidade do sistema à existência ou não de usuários sendo cobertos a cada instante).

Uma maneira de abordar os problemas de confiabilidade acima citados de *ERBs* fixas é a realocação das mesmas. [Younis and Akkaya 2008] estudou a realocação de *ERBs* ao longo do tempo e discutiu as questões de quando relocar, onde relocar e como gerenciar as realocações para aumentar a confiabilidade da rede. Tais aspectos se concentraram em três atributos principais: a longevidade da rede (por exemplo, otimizando o equilíbrio do tráfego), a pontualidade na entrega de dados (por exemplo, evitando ou minimando o congestionamento do tráfego de dados) e a segurança física. No entanto, as melhorias de desempenho em termos de rendimento, energia e atraso pelo reposicionamento da *ERB* apresentam seus próprios desafios (logística, viabilidade comercial, etc.) e não abordam totalmente as situações que envolvem padrões complexos de mobilidade do usuário, algo comum em muitos cenários.

Trabalhos relacionados incluem o Gowda, que propôs o uso de pontos de acesso móveis em redes internas, *iMob* [Gowda et al. 2016]. Nesse caso, a meta-heurística Optimal Stopping Theory (*OST*) foi usada para definir a realocação dos pontos de acesso.

Para esse mesmo tipo de problema, [Karvounas et al. 2010] utilizou Simulated Annealing (*SA*) e Ant Colony Optimization (*ACO*) para otimizar a posição dos pontos de acesso em relação aos usuários.

Em Redes de Sensores Sem Fio (*RSSF*), a questão dos problemas de otimização relacionados à cobertura é abordada por [Liu 2015], que trata do problema de perda de conectividade de nós usando um método de otimização global para localizar uma árvore minimamente conectada, enquanto adota um algoritmo de recuperação para substituir os nós ausentes. A técnica também emprega um esquema de agendamento hierárquico que se baseia no pré-tratamento da falha do nó. [Guo et al. 2017] modelou um problema de otimização com restrições, equilibrando a cobertura de rede e o consumo de energia. O objetivo era obter cobertura máxima dos nós, com informações sobre a taxa de cobertura e consumo de energia dos nós ativos, onde a importância de nós individuais é função da distância de seus pares.

Para redes veiculares, uma abordagem muito estudada é explorar os dispositivos computacionais e de comunicação embutidos em veículos para estabelecer uma rede veículo-veículo (*V2V*) em vez de depender da infraestrutura local [Wu et al. 2004]. Esse arranjo faz com que veículos trafeguem constantemente informações sobre si mesmos e requeira suporte criptográfico sofisticado para superar problemas de privacidade [Freudiger et al. 2007, Petit et al. 2015]. Os nós de rede não devem estar a muitos saltos de um nó com acesso direto à Internet [Gerla and Kleinrock 2011], o que pode ser um problema para confiar na tecnologia de ERBs estáticas em zonas escassamente povoadas. No caso de [Ding et al. 2007], um modelo e seu correspondente estudo de simulação de uma rede multi-hop com nós móveis auxiliados por nós estáticos foram apresentados, mostrando melhora no caso de baixa densidade de veículos. [Zhou et al. 2015] defendem o uso de Veículos Aéreos Não Tripulados (*VANTs*) como nós de redes auxiliares para redes terrestres e *V2V* e fornecem ao leitor uma revisão sobre o estado da arte nessa área.

Algoritmos heurísticos de otimização têm sido usados no projeto e gerenciamento de redes sem fio. Para Redes de Sensores Distribuídos (*RSD*), Lin e Chiu apresentaram uma solução para o problema de posicionamento do sensor usando o método *SA* para obter o posicionamento ideal de sensores, minimizando o erro máximo de distância, usando uma limitação de custo mínimo [Lin and Chiu 2005]. [Kang et al. 2017] usou o método Genetic Algorithm (*GA*) para otimização multiobjetivo da posição e caminhos dos coletores de dados em *RSSF*, com foco na manutenção da conectividade. Algoritmos heurísticos de otimização como Artificial Bee Colony (*ABC*) também são usados para projetar Phased Array Antennae (*PAA*) [Zhang and Zhang 2017].

3. Fundamentação teórica

As idéias propostas neste trabalho envolvem a adaptação dinâmica da configuração de rede (ou seja, o reposicionamento de *RRBSs*) para melhorar o número de usuários cobertos, onde os mesmos representam um padrão de mobilidade complexo. Portanto, a avaliação adequada dessas idéias exige modelos que reproduzam de forma confiável os padrões de movimento dos detentores de dispositivos sem fio. Esses modelos devem considerar a forte influência da forma da área coberta nos padrões de movimentos do usuário [Lee et al. 2012].

O estudo dos padrões de movimentação humana tornou-se viável através do desen-

volvimento de ferramentas que monitoram os locais visitados por pessoas em um determinado local ao longo do tempo [Kang et al. 2012]. Determinar a localização geográfica de dispositivos móveis através da localização do telefone celular é uma maneira apropriada de coletar dados para estudar a mobilidade de usuários em larga escala [Kang et al. 2010].

[Lee et al. 2012] propôs o Self-Similar Least-Action Human Walk (*SLAW*), um modelo no qual um grupo de lugares é gerado no espaço 2D e os usuários são colocados aleatoriamente para formar a configuração inicial. Em seguida, as etapas subsequentes são definidas usando o algoritmo Least Action Trip Planning (*LATP*), que produz traços de mobilidade com características estatísticas específicas observadas em dados de mobilidade humana, ou seja, tempos de espera da lei de potência e distâncias de deslocamento com distribuição de cauda pesada. [Kosta et al. 2010] propôs o modelo Small World In Motion (*SWIN*), que também define aleatoriamente uma posição preliminar e as localizações subsequentes são calculadas usando um método de ponderação. Finalmente, [Pappalardo and Simini 2016] propôs o modelo Exploration and Preferential Return (*ERP*), que emprega uma abordagem distinta dos dois modelos anteriores. Em vez de começar com um ponto inicial aleatoriamente definido em um espaço bidimensional, *ERP* usa um algoritmo baseado em dados que constrói um gerador de diário a partir de dados reais, capturando a tendência dos indivíduos de seguir ou quebrar suas rotinas. Ele usa esse conhecimento para estimar os lugares mais prováveis para onde os usuários iriam, o que será a base para a localização inicial de cada usuário.

Analisando os modelos mencionados, concluímos que todos são capazes de gerar padrões de locomoção humana, analisando um conjunto de informações passadas por processos, utilizando probabilidades de ocorrência de eventos e empregando técnicas de ponderação. Modelos de exploração podem ter razoável sucesso em reproduzir bem as peculiaridades do movimento humano, mas há menos precisão nos padrões humanos temporais. No lado oposto, os modelos temporais são geralmente mais capazes de reproduzir a mobilidade humana em tempo hábil, mas são menos precisos e não capturam totalmente a complexidade dos padrões. Para este trabalho, objetivamos desenvolver um modelo que combine tanto os benefícios dos modelos de exploração quanto os dos modelos temporais, enquanto capta adequadamente tanto a heterogeneidade da mobilidade humana quanto a regularidade do movimento dos indivíduos.

Entre os modelos que analisamos em nossa pesquisa, o que apresentou a maior similaridade com dados reais foi o *DITRAS* [Pappalardo and Simini 2016], que pode representar rotas e dados sucintos que reproduzem de perto movimentos humanos reais. Este modelo funciona basicamente com duas estruturas correlatas: a geração de um diário de mobilidade (uma ferramenta que captura os padrões de mobilidade humana especificando o tempo de chegada e o tempo gasto em cada local visitado pelos indivíduos) e a trajetória de mobilidade (a qual descreve a movimentação de um indivíduo como uma sequência de posições registradas ao longo do tempo), reproduzindo assim a mobilidade de indivíduos em uma determinada região.

O algoritmo de otimização baseado na técnica *Simulated Annealing SA* foi utilizado para alcançar os resultados dos experimentos. Esta técnica desenvolvida por [Kirkpatrick et al. 1983] é advinda da mecânica estatística e é baseado num processo utilizado para fundir um metal qualquer, onde o mesmo é aquecido a uma temperatura elevada e logo em seguida resfriado lentamente, de maneira que o resultado final produza

uma massa homogênea.

Já o *GMM* [Reynolds 2009] é um modelo probabilístico para representar a presença de sub-populações dentro de uma população geral, sem exigir que um conjunto de dados observados devam identificar as sub-populações que pertençam a uma observação individual. Neste caso, são encontrados os centroides destas subpopulações e para este problema estes centroides serão os pontos onde serão alocadas as *RRBSs*

A comparação entre o *SA*, método de otimização meta heurístico, e o *GMM*, método de clusterização por aprendizagem de máquina, é útil pois o primeiro método nos permite definir a qualidade do resultado esperado pelo número de iterações e o segundo método define seu próprio número de iterações para seu objetivo. Assim podemos comparar o tempo de execução de cada método com seus respectivos resultados (número de usuários cobertos).

4. Metodologia

4.1. Simulated Annealing

O presente trabalho tem por finalidade a avaliação da realocação dinâmica de *ERBs* para melhorar a cobertura oferecida a uma rede sem fio. Propomos modelar *ERBs* embarcadas em robôs aéreos (quadrópteros, balões ou qualquer dispositivo programável capaz de voar, como pode ser visto na Figura 2). Uma das principais vantagens das *RRBSs* é a capacidade de reposicionamento em determinada área para aumentar o número de usuários cobertos. No esquema proposto, a posição relativa de *RRBSs* em relação aos usuários é determinada dinamicamente por *SA*.




Figura 2. Estrutura de rede sem fio com a proposta de *RRBSs*.

Iremos apresentar agora a formulação ao problema da relocação de *RRBS*. Suponha que no instante k as posições de m usuários estejam disponíveis no vetor $U_k = [U_k(1), \dots, U_k(m)]^T$. Vamos supor também que existem exatamente n *RRBSs*

para esta tarefa com posições no vetor $R_k = [R_k(1), \dots, R_k(n)]^T$, para cada instante k . A tarefa é encontrar valores ótimos para R_k , denominados R_k^* , para todos os k , em intervalos discretos de posições de usuários gerados pelo algoritmo *DITRAS*.

Seja h uma função que retorna a distância entre o usuário u e a *RRBS* mais próxima $h : u \in U_k \times R_k \rightarrow \mathbb{R}$ definido em 1.

$$h(u, R_k) = \min_{1 \leq i \leq n} \{\|U_k(u) - R_k(i)\|_2\}. \quad (1)$$

Considerando que uma *RRBS* é capaz de fornecer sinal em um círculo com um raio fixo γ , e tomando x como uma distância qualquer entre um usuário e a *RRBS* mais próxima, seja $s : \mathbb{R} \rightarrow \{0, 1\}$ uma função auxiliar utilizada para verificar a cobertura dos usuários, conforme definido na Equação 2.

$$s(x) = \begin{cases} 1 & \text{se } x < \gamma \\ 0 & \text{caso contrário} \end{cases} \quad (2)$$

Note que a composição de h com s retorna se um usuário arbitrário u é atendido ou não pela rede de *RRBSs*. Assim, o número total de usuários atendidos pelo conjunto de *RRBSs* R_k no instante k é avaliado por $S : U_k \times R_k \rightarrow \mathbb{N}$ (Equação 3).

$$S(U_k, R_k) = \sum_{i=1}^m s \circ h(U_k(i), R_k) \quad (3)$$

Assim, dado um conjunto de *RRBSs* e um conjunto de usuários para fornecer serviço num instante k , o objetivo é definido conforme descrito na Equação 4.

$$F = \max_{R_k} S(U_k, R_k) \quad (4)$$

Uma preocupação a respeito da Equação 4 é que não há penalidade para múltiplas *RRBSs* fornecerem sinal para um mesmo usuário. Para evitar isso, vamos definir a soma de todos os links entre *RRBSs* e usuários como $G : U_k \times R_k \rightarrow \mathbb{N}$ na Equação 5.

$$G(U_k, R_k) = \sum_{i=1}^m \sum_{j=1}^n s \circ \|U_k(i) - R_k(j)\|_2 \quad (5)$$

Agora defina $P : U_k \times R_k \rightarrow \mathbb{Z}$, Equação 6, uma função que retorna a penalidade para múltiplos links fornecidos. Consideramos que o link fornecido por apenas uma *RRBS* é suficiente para atender a cada usuário.

$$P(U_k, R_k) = G(U_k, R_k) - S(U_k, R_k) \quad (6)$$

Seja $C : U_k \times R_k \rightarrow \mathbb{Z}$ uma função utilizada para verificar o número total de usuários atendidos pelo conjunto de *RRBSs* R_k , porém considerando a penalidade da Equação 6, conforme definido na Equação 7:

$$\begin{aligned} C(U_k, R_k) &= S(U_k, R_k) - P(U_k, R_k) \\ &= 2S(U_k, R_k) - G(U_k, R_k) \end{aligned} \quad (7)$$

Considerando as penalidades, a Equação 3 se transforma na Equação 7. Então, dado um conjunto de $RRBSs$ e um conjunto de usuários para fornecer serviço no instante k , a função objetivo é definida conforme vemos na Equação 8.

$$F = \max_{R_k} C(U_k, R_k) \quad (8)$$

Neste ponto, um pequeno número de estratégias de solução está disponível. Suponhamos que a dinâmica de movimentação dos usuários seja desconhecida, que todos as $RRBSs$ possam fornecer o serviço individualmente e que todos as $RRBSs$ e posições dos usuários sejam conhecidos. Com base nessas suposições, as posições ideais das $RRBSs$ iniciais R_0^* são alcançadas resolvendo-se o problema de otimização sem restrições na Equação 9.

$$R_0^* = \operatorname{argmax}_{R_0} C(U_0, R_0) \quad (9)$$

Admitindo a existência de uma região de interesse, $\Pi_{k=0}$, sobre a qual o número de usuários atendidos deve ser maximizado, então o problema formulado tem n variáveis reais bidimensionais (já que cada posição da $RRBS$ $R_0(i) \in R_0$ tem 2 coordenadas) restrito ao conjunto Π_0 , que tem m usuários no instante $k = 0$. É fácil ver que o problema cresce exponencialmente com robôs, usuários e tamanho da região. Devido a esse crescimento, o uso de um método meta-heurístico, como GA , ABC ou SA , é justificado.

É importante enfatizar que os métodos de busca de mínimos e máximos globais baseados em meta-heurísticas são sensíveis à parametrização e, portanto, uma parametrização adequada para qualquer um dos métodos mencionados seria capaz de aproximar a solução. Como prova de conceito, escolhemos SA [Kirkpatrick et al. 1983]. Também é possível usar uma variante mais eficiente em processamento, conforme verificado em [Ingber 1993] ou até mesmo outra técnica de busca heurística, contudo como o objetivo deste trabalho não é comparar a eficiência destes métodos. e como os mesmos são baseados em buscas aleatórias, não temos garantia de melhor qualidade dos resultados deste experimento ao utilizar um ou outro método meta-heurístico.

Para este trabalho, a ideia desta metaheurística advinda da metalurgia, a qual baseia-se no resfriamento gradativo de um material a partir de uma alta temperatura inicial que o leva a estados mínimos de energia, se resume em dar total liberdade na região (iniciar com máxima temperatura, decrescendo ao longo das iterações) para o conjunto de $RRBSs$ avaliar como seria a cobertura da rede, a partir de variados reposicionamentos (o qual depende do número de iterações) das $RRBSs$ na região, e guardar qual posicionamento gerou maior cobertura de usuários da rede. A aleatoriedade do reposicionamento do conjunto de $RRBSs$ a cada iteração (perturbação) é feito com um ruído gaussiano, o qual depende também da temperatura. A estratégia usando o SA é:

1. Inicialize aleatoriamente o conjunto $R_0^{j=0}$ dentro de Π_0 e a temperatura do sistema como $T^{j=0} = T_{max}$;

2. Avalie $C(U_0, R_0^j)$;
3. Perturbe cada $R_k(i) \in R_0^j$ com ruído Gaussiano, $\mathcal{N}(0, \sigma^2)$, em que σ^2 é baseado em T^j para obter R_0^{j+1} . Assegure-se de que $R_0^{j+1} \in \Pi_0$;
4. Avalie $C(U_0, R_0^{j+1})$;
5. Mova para este novo conjunto se o custo for igual ou maior que o anterior ou mover de qualquer maneira com uma probabilidade relacionada a T^j ;
6. Reduza a energia do sistema ($T^{j+1} < T^j$);
7. Incremente j e repita os passos 3 a 6 até $T^j < T^{min}$;
8. Defina R_0^+ como o último valor mínimo de R_0^j . Esta é uma solução sub-ótima encontrada;

Escolhas adequadas de T_{min} , T_{max} , amplitude de perturbação e queda de temperatura são essenciais para a solução convergir. Essa classe de técnicas não garante viabilidade ou convergência para um mínimo global, mas diferentemente das técnicas baseadas em gradientes, é menos vulnerável a ficar bloqueado em mínimos locais, pois há subconjuntos de Π_0 tais que S é constante. Também sabemos que S é descontínuo e sua derivada nem sempre é possível de ser calculada. Além disso, pelo menos é possível garantir que $C(U_0, R_0^0) \leq C(U_0, R_0^+) \leq C(U_0, R_0^\infty) \leq C(U_0, R_0^*)$, ou seja, a solução após a busca heurística é melhor ou igual ao ponto inicial original.

4.2. Gaussian Mixture Model

Para esta técnica, analogamente ao que foi feito no *SA*, queremos encontrar um conjunto de pontos que representem o posicionamento ótimo ou subótimo das *RRBSs*. Para tanto, o algoritmo trabalha da seguinte forma:

O método ajusta o modelo aos dados usando o algoritmo iterativo de *Expectation – Maximization (EM)*. Usando valores iniciais para médias de componentes, matrizes de covariância e proporções de mistura, o algoritmo *EM* trabalha em duas etapas:

- Para cada observação, o algoritmo calcula probabilidades posteriores de associação entre componentes. São inicializados os parâmetros de distribuição, como médias, covariâncias e coeficientes de mistura, e avaliado o valor inicial da probabilidade logarítmica (a qualidade do ajuste da distribuição atual em relação ao conjunto de dados de observação). Após isto, são avaliadas as responsabilidades (ou seja, fatores de peso de cada amostra) usando os valores atuais dos parâmetros. Este é o passo *E* do algoritmo *EM*.
- Usando as probabilidades posteriores da associação ao componente como pesos, o algoritmo estima as médias do componente, matrizes de covariância e proporções de mistura aplicando a máxima verossimilhança. Este é o passo *M* do algoritmo *EM*.

O algoritmo repete essas etapas até a convergência. A superfície de probabilidade é complexa e o algoritmo pode convergir para um ótimo local. Além disso, o ótimo local resultante pode depender das condições iniciais. Os detalhes deste método podem ser verificados em [Reynolds 2009].

Agora que temos os clusters, nos falta encontrar o centróide de cada cluster para que estes pontos sejam os pontos de posicionamento das *RRBSs*. Para encontrar os centróides utilizaremos a técnica *k – means*:

O algoritmo *k - means* [Alsabti et al. 1997] usa uma heurística para encontrar sementes de centróide para o agrupamento de *k - means*. O algoritmo anterior pode aplicar o mesmo princípio para inicializar o *EM* usando o algoritmo *k - means* para selecionar os valores dos parâmetros iniciais para um modelo de mistura Gaussiano ajustado. O *k - means* assume que o número de clusters é *k* e escolhe os valores iniciais dos parâmetros da seguinte maneira:

- Selecione a probabilidade da mistura de componentes para ser a probabilidade uniforme $p_i = 1/k$ onde $i = 1, \dots, k$;
- Selecione as matrizes de covariância para serem diagonais e idênticas, onde $\sigma_i = \text{diag}(a_1, a_2, \dots, a_k)$ e $a_j = \text{var}(X_j)$;
- Selecione o primeiro centro de componente inicial μ_1 uniformemente de todos os pontos de dados em X ;
- Para escolher o centro j :
 - Calcule as distâncias de Mahalanobis de cada observação para cada centróide e atribua cada observação ao centróide mais próximo, e;
 - Para $m = 1, \dots, n$ e $p = 1, \dots, j - 1$ selecione o centróide j aleatoriamente de X com probabilidade $\frac{d^2(x_m, \mu_p)}{\sum_{h: x_h \in M_p} d^2(x_h, \mu_p)}$, onde $d(x_m, \mu_p)$ é a distância entre a observação m e μ_p , e M_p é o conjunto de todas as observações mais próximas do centróide μ_p e x_m pertence a M_p .
Ou seja, selecione cada centro subsequente com uma probabilidade proporcional à distância entre si e o centro mais próximo que você já escolheu.
- Repita o passo 4 até que *k* centróides sejam escolhidos.

4.3. Experimento

Para avaliar a eficiência dos algoritmos *SA* e *GMM* na intenção de encontrar as posições desejadas das *RRBSs* de maneira que a cobertura seja razoável em determinado cenário, iremos rodar 30 vezes de 100 a 1 000 000 iterações do *SA* e 30 vezes até a convergência do *GMM*, com as seguintes condições:

- em uma região aleatória de 2.52 km²;
- com 100 usuários uniformemente distribuídos;
- com 7 *RRBSs* com cobertura circular de 140 m de raio.

Avaliando as seguintes métricas referentes ao número de usuários cobertos:

- máximo;
- mínimo;
- moda;
- média;
- mediana;
- desvio padrão;
- tempo de execução do algoritmo.

5. Resultados obtidos

Usamos o *DITRAS* para gerar 1 amostra de 100 posições de usuários. A região é semelhante à região de Trentino na Itália, como mostrado na Figura 3. A tarefa é fornecer cobertura para os 100 usuários utilizando *GMM* e *SA* em cada amostra de posições do usuário, com o intuito de avaliar a otimização da cobertura em um mesmo instante de tempo.




Figura 3. A região explorada pelos usuários durante o experimento.

5.1. GMM

Na figura 4 podemos observar a quantidade de usuários cobertos em cada uma das 30 vezes que o algoritmo rodou. Nesta ocasião, foram obtidos os seguintes resultados:

- o valor máximo: 63
- o valor mínimo: 42
- a média: 51.6333
- a mediana: 51
- a moda: 50
- o desvio padrão: 4.6199
- o tempo gasto para as 30 vezes que o *GMM* rodou: 35.9065 segundos

5.2. SA

Nas figuras 5, 6, 7 e 8 podemos verificar a convergência e as respectivas métricas referentes ao *SA* para os seguintes números de iterações:

- | | | |
|---------|----------|-------------|
| • 100 | • 5 000 | • 90 000 |
| • 200 | • 6 000 | • 100 000 |
| • 300 | • 7 000 | • 200 000 |
| • 400 | • 8 000 | • 300 000 |
| • 500 | • 9 000 | • 400 000 |
| • 600 | • 10 000 | • 500 000 |
| • 700 | • 20 000 | • 600 000 |
| • 800 | • 30 000 | • 700 000 |
| • 900 | • 40 000 | • 800 000 |
| • 1 000 | • 50 000 | • 900 000 |
| • 2 000 | • 60 000 | • 1 000 000 |
| • 3 000 | • 70 000 | |
| • 4 000 | • 80 000 | |




Figura 4. Resultados de cobertura dos usuários ao longo das 30 vezes que o *GMM* rodou.




Figura 5. Convergência do *SA*, com as respectivas métricas relativas.




Figura 6. Tempo gasto para cada 30 vezes em que o algoritmo foi rodado para cada número de iteração. Nesta figura, considera-se as os números de iterações de 100 a 10 000.




Figura 7. Tempo gasto para cada 30 vezes em que o algoritmo foi rodado para cada número de iteração. Nesta figura, considera-se as os números de iterações de 100 a 1 000 000.

5.3. Discussão sobre os resultados

A curva de convergência do *SA* nos mostra todo esforço computacional que um método matemático de otimização meta heurístico toma para encontrar o valor ótimo esperado, com o respectivo tempo utilizado.

Uma forma razoável de comparar os resultados do *GMM* e *SA* seria verificar




Figura 8. O desvio padrão para os números de iterações de 100 a 10 000 000.

as métricas referentes a um mesmo tempo gasto para as 30 execuções. Para tanto, os números de iterações 700 e 800 do *SA* foram os que tiveram tempo de execução mais próximos do tempo de execução do *GMM*:

- | | |
|--|--|
| • o valor máximo: 55 | • o valor máximo: 59 |
| • o valor mínimo: 45 | • o valor mínimo: 45 |
| • a média: 49.3000 | • a média: 49.4333 |
| • a mediana: 49 | • a mediana: 49 |
| • a moda: 47 | • a moda: 49 |
| • o desvio padrão: 2.9729 | • o desvio padrão: 3.2556 |
| • o tempo gasto para as 30 vezes com 700 iterações do <i>SA</i> : 33.3709 segundos | • o tempo gasto para as 30 vezes com 800 iterações do <i>SA</i> : 36.3736 segundos |

Notemos que o *SA*, já considerando a divisão pelo número de vezes que o algoritmo rodou para fins estatísticos, demorou aproximadamente $40000/30 = 1333.33$ segundos (em torno de 25 minutos) para encontrar os melhores resultados médios, aproximadamente 61 usuários cobertos. Considerando a complexa, dinâmica e constante movimentação dos usuários em qualquer rede, este seria um tempo impraticável para uma *RRBS* recalcular seu posicionamento para reajustar as posições ótimas e assim oferecer melhor cobertura aos usuários.

Por outro lado, tomando por base o tempo de convergência do *GMM* que foi $35.9065/30 = 1.2$ segundos (tempo razoável para os cálculos de reposicionamento das *RRBSs*), e já considerando este resultado melhor que o do *SA* com o mesmo tempo gasto, temos um resultado médio de aproximadamente 52 usuários cobertos. Este resultado é 15% menor que o do *SA* com 1 milhão de iterações porém gastou 0.09% do tempo, ou seja, gastou 99.91% de tempo a menos para ter 85% do resultado.

6. Conclusão

Para este experimento, verificamos que o esforço computacional para encontrar posições ótimas das *RRBSs* demanda um tempo maior que o razoável para um reposicionamento dinâmico em condições que os usuários se movam constantemente.

Também verificamos que a técnica de aprendizado de máquina *GMM* apresenta melhores resultados que a técnica de otimização meta heurística *SA*, quando se deseja razoabilidade de execução de tempo do método, desejando ter pronta resposta de posicionamento do sistema.

Referências

- Alsabti, K., Ranka, S., and Singh, V. (1997). An efficient k-means clustering algorithm.
- Ding, Y., Wang, C., and Xiao, L. (2007). A static-node assisted adaptive routing protocol in vehicular networks. In *Proceedings of the fourth ACM international workshop on Vehicular ad hoc networks*, pages 59–68. ACM.
- Freudiger, J., Raya, M., Félegyházi, M., Papadimitratos, P., and Hubaux, J.-P. (2007). Mix-zones for location privacy in vehicular networks. In *ACM Workshop on Wireless Networking for Intelligent Transportation Systems (WiN-ITS)*, number LCA-CONF-2007-016.
- Gerla, M. and Kleinrock, L. (2011). Vehicular networks and the future of the mobile internet. *Computer Networks*, 55(2):457–469.
- Gowda, M., Dhekne, A., and Roy Choudhury, R. (2016). The case for robotic wireless networks. In *Proceedings of the 25th International Conference on World Wide Web, WWW '16*, pages 1317–1327.
- Guo, Y.-n., Cheng, J., Liu, H.-y., Gong, D., and Xue, Y. (2017). A novel knowledge-guided evolutionary scheduling strategy for energy-efficient connected coverage optimization in wsns. *Peer-to-Peer Networking and Applications*, 10(3):547–558.
- Hayat, S., Yanmaz, E., and Muzaffar, R. (2016). Survey on unmanned aerial vehicle networks for civil applications: A communications viewpoint. *IEEE Communications Surveys & Tutorials*, 18(4):2624–2661.
- Howard, R. A. (2012). *Dynamic probabilistic systems: Markov models*, volume 1. Courier Corporation.
- Ingber, L. (1993). Simulated annealing: Practice versus theory. *Mathematical and Computer Modelling*, 18(11):29 – 57.
- Kang, C., Gao, S., Lin, X., Xiao, Y., Yuan, Y., Liu, Y., and Ma, X. (2010). Analyzing and geo-visualizing individual human mobility patterns using mobile call records. In *Geoinformatics, 2010 18th International Conference on*, pages 1–7. IEEE.
- Kang, C., Ma, X., Tong, D., and Liu, Y. (2012). Intra-urban human mobility patterns: An urban morphology perspective. *Physica A: Statistical Mechanics and its Applications*.
- Kang, Z., Zeng, H., Hu, H., Xiong, Q., and Xu, G. (2017). Multi-objective optimized connectivity restoring of disjoint segments using mobile data collectors in wireless sensor network. *EURASIP Journal on Wireless Communications and Networking*, 2017(1):65.

- Karvounas, D., Tsagkaris, K., and Demestichas, P. (2010). Position optimization for moving access points. *2010 Future Network and Mobile Summit*, pages 1–8.
- Kirkpatrick, S., Gelatt, C. D., and Vecchi, M. P. (1983). Optimization by simulated annealing. *science*, 220(4598):671–680.
- Kosta, S., Mei, A., and Stefa, J. (2010). Small world in motion (swim): Modeling communities in ad-hoc mobile networking. In *Sensor Mesh and Ad Hoc Communications and Networks (SECON), 2010 7th Annual IEEE Communications Society Conference on*, pages 1–9. IEEE.
- Lee, K., Hong, S., Kim, S. J., Rhee, I., and Chong, S. (2012). Slaw: self-similar least-action human walk. *IEEE/ACM Transactions on Networking (TON)*, 20(2):515–529.
- Lin, F. Y. and Chiu, P.-L. (2005). A near-optimal sensor placement algorithm to achieve complete coverage-discrimination in sensor networks. *IEEE Communications Letters*, 9(1):43–45.
- Liu, Guo, C. Z. (2015). A hierarchical scheduling scheme in wsns based on node-failure pretreatment. *International Journal of Distributed Sensor Networks*, 11:7.
- Padueli, M. P. (2012). As estacoes radio base na cidade de sao paulo: uma abordagem sobre os riscos e uma contribuicao para os sistemas de gerenciamento.
- Pappalardo, L. and Simini, F. (2016). Modelling individual routines and spatio-temporal trajectories in human mobility. cite arxiv:1607.05952.
- Petit, J., Schaub, F., Feiri, M., and Kargl, F. (2015). Pseudonym schemes in vehicular networks: A survey. *IEEE communications surveys & tutorials*, 17(1):228–255.
- Rahmati, A., He, X., Guvenc, I., and Dai, H. (2019). Dynamic mobility-aware interference avoidance for aerial base stations in cognitive radio networks. *arXiv preprint arXiv:1901.02613*.
- Rappaport, T. (2001). *Wireless Communications: Principles and Practice*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd edition.
- Reynolds, D. A. (2009). Gaussian mixture models. *Encyclopedia of biometrics*, 741.
- Wu, H., Fujimoto, R., Guensler, R., and Hunter, M. (2004). Mddv: a mobility-centric data dissemination algorithm for vehicular networks. In *Proceedings of the 1st ACM international workshop on Vehicular ad hoc networks*, pages 47–56. ACM.
- Younis, M. and Akkaya, K. (2008). Node positioning for increased dependability of wireless sensor. *Algorithms and Protocols for Wireless Sensor Networks*, 62:225.
- Zhang, X. and Zhang, X. (2017). A non-revisiting artificial bee colony algorithm for phased array synthesis. *EURASIP Journal on Wireless Communications and Networking*, 2017(1):7.
- Zhou, Y., Cheng, N., Lu, N., and Shen, X. S. (2015). Multi-uav-aided networks: aerial-ground cooperative vehicular networking architecture. *ieee vehicular technology magazine*, 10(4):36–44.